

신경회로망을 이용한 Single-line Display Menu의 수행도 예측모형

Performance model of the single-line display menu using neural network approach

곽지영

포항공과대학교 산업공학과

Abstract

A lot of design guidelines have been proposed for menu-driven interfaces, but they are applicable only to the menus on ordinary CRT displays. Many hardware products, however, cannot employ large displays because of the cost and space limitations. Instead, a single-line display menu (SDM) is widely used, and the designers need useful guidelines applicable to the SDM. A focus is often placed upon the optimal menu structure, but only the standard menu structures, such as 64^1 , 8^2 , 4^3 , and 2^6 , are tested for optimality. In many cases, however, ill defined or asymmetric structures are suggested as design alternatives. To determine the optimal menu structure, user performance should be obtained in terms of quantitative measures for each of the optional structures considered. Hence, a model is needed to provide a predicted value of user performance for a given menu structure. Although several models have been proposed for ordinary menus, none is available for the SDM yet. A performance model was developed in this study using the neural network approach. A The model developed in this study is capable of providing quantitative measures of human performance for any menu structures without conducting additional experiments, which will save much time and reduce the design cost.

1. 서 론

전자제품과 같은 하드웨어의 사용자 인터페이스는 시스템의 기능을 사용자에게 적절한 형태로 제시하여, 사용자가 원하는 기능을 쉽고 빠르게 선택할 수 있도록 하는 데 주목적이 있다. 따라서, 하드웨어에서도 소프트웨어에서 주로 이용되어 온 메뉴 방식의 인터페이스가 많이 이용되고 있다. 소프트웨어의 경우, 메뉴항목은 약 13인치 이상의 일반적인 크기의 스크린을 통해 제시되므로 여러 메뉴항목이 한 화면에 동시에 표시될 수가 있는 데 반하여, 하드웨어의 메뉴 설계시에는 비용이나 공간적인 제약으로 인하여, 큰 스크린의 설치가 불가능하다. 하드웨어의 사용자 인터페이스로서 LCD와 같은 작은 화면에 메뉴항목을 한 항목씩 차례로 제시해 주는 인터페이스가 가장 많이 이용된다(그림 1 참조). 이와 같은 형태의 인터페이스는 Single-line Display Menu (SDM)로 정의된다. SDM은 한 화면에 한 항목만이 표시 가능하므로 메뉴 진행경로 (Navigation Path)가 매우 복잡하며, 복잡한 진행경로를 시작적으로 표시할 수가 없다는 특성을 갖는다. 따라서, 설계시 고려사항도 일반적인 메뉴와는 달라져야 하며, SDM의 설계특성이 잘 반영된 고유한 설계지침이 제시되어야 한다.

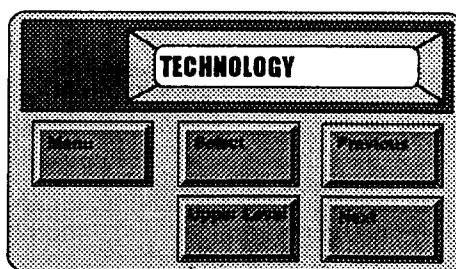


그림 1. Single-line Display Menu의 예

본 연구에 앞서 SDM에 대하여 실험적 결과를 바탕으로 한 설계지침을 제시하기 위한 연구가 수행되어, 현재 메뉴구조에 대한 설계지침이 제시되어 있다[1, 3, 4]. 이 연구에서는 64^1 , 8^2 , 4^3 , 2^6 등의 몇 가지 전형적인 메뉴구조에 대한 평가만이 실시되었으나, 실제 메뉴의 설계시에는 이외의 다소 복잡한 메뉴구조들도 설계대안으로서 고려될 필요가 있으며, 설계대안이 되는 모든 메뉴구조에 대한 수행도가 정량적으로 제시되어야 설계대안들 간의 비교가 가능하다. 그러나, 모든 메뉴구조에 대하여 실험평가를 실시하는 것은 불가능하므로, 대표적인 몇 가지 대안에 대한 실험결과만을 이용하여, 일반적인 메뉴구조에 대한 수행도를 예측할 수 있는 수행도 예측모델의 개발이 필요하다.

2. SDM의 수행도 예측모델

현재까지 일반적인 메뉴에 대한 수행도 모델은 상당수가 제시되고 있으나[2, 5, 6, 7], 다음과 같은 이유로 인해 예측도가 상당히 낮으며, 설계상의 많은 차이를 보이게 되는 SDM에는 적용이 불가능하다. 첫째, 같은 Depth Level의 메뉴항목 중 한 항목을 선택하기까지 검사된 항목의 수와 한 항목당 소요된 시간이 모든 Depth Level에서 일정한 것으로 가정하고 있으나, 각 Depth Level에서의 Decision Making의 난이도에 차이가 있으며, Choice Reaction Time에도 차이가 있을 수 있으므로 Depth Level에 따라 달라질 수 있다. 둘째, 전체 수행시간의 계산에 있어서도 한 Depth Level에서의 수행시간에 메뉴의 Depth를 곱하여 계산하였으나, Depth Level의 차이에 대한 고려가 필요하다. 셋째, 일반적인 메뉴에서는 같은 Depth Level 내에서 한 항목을 선택할 경우 버튼 조작이 없이 Saccadic Movement 만으로 항목간의 이동이 가능한 반면, SDM은 같은 Depth Level 내의 메뉴항목 간 이동에도 버튼조작이 필요하다.

이러한 무리한 가정과 그로 인한 문제점을 보완하고, SDM의 특성에 맞는 수행도 예측을 위하여 다음과 같은 형태의 모델을 제시할 수 있다. 식에서 $E(n_i)$ 는 같은 Depth Level i 내에서 한 항목이 선택되기까지 검사된 항목수의 평균이고, t_i 는 한 항목당 소요된 시간이다. k 와 α 는 각각 버튼조작시간과 시스템의 반응시간으로 상수로 가정하였다.

$$\text{Search Time} = \sum_{i=1}^{\text{Depth}} \{E(n_i)(t_i + k + a)\}$$

주어진 메뉴구조에 대한 작업수행시간을 예측하고자 할 경우, 식에서 $E(n_i)$ 와 t_i 에 예측치를 대입하면 된다. 이때, 두 Parameter의 예측치의 계산에는 메뉴구조의 Depth, Breadth 및 Depth Level에 대한 정보가 반영되어야 한다. 본 연구에서는 신경회로망을 이용하여 각 Depth Level에서의 $E(n_i)$ 와 t_i 를 예측하는 모델을 개발하였다.

3. 사용된 Network

3.1 Network의 종류 및 구조

본 연구에서는 i 번째 Depth Level 내에서 한 항목이 선택되기까지 검색된 항목의 수 $E(n_i)$ 와 한 항목당 소요되는 시간 t_i 를 예측하기 위한 Neural Network을 각각 Multi-layer Perceptron (MLP)을 이용하여 구성하였다. 두 경우 모두, 메뉴구조의 Depth와 Breadth, Depth Level의 세 가지 정보를 Network의 Input으로 하며, 작업수행시간의 예측치를 Output으로 하였다.

3.2 학습방법

본 연구에 앞서 32명의 피실험자를 대상으로 인간공학 실험을 수행하여 얻은 약 500여개의 Input-Output Pattern의 Training Set으로 이용되었다. Training Set 중 150개의 Input-Output Pattern

을 임의로 선택하여, Cross Validation에 이용하였고, 약 350여개만을 이용하여 Network의 학습을 실시하였다. 학습방법으로는 Momentum Term을 포함하는 Back-propagation이 이용되었다. Hidden Node에서는 Logistic Function이 Activation Function으로 이용되었고, Output Node에는 Linear Activation Function을 적용하였다. Hidden Node의 수와 Learning Parameter는 임의의 값에 대하여 학습을 실시한 후 Cross Validation의 결과가 좋은 값으로 선정하였다.

4. 결과 및 모델의 평가

학습의 결과, Hidden Node의 수가 각각 14, 10인 그림 2, 3과 같은 Network이 가장 적절한 것으로 평가되었다. 학습에 적용된 Learning Parameter와 Epoch의 수, Mean Squared Error(MSE), Cross Validation Set에 대한 MSE를 표 1에 요약하였다.

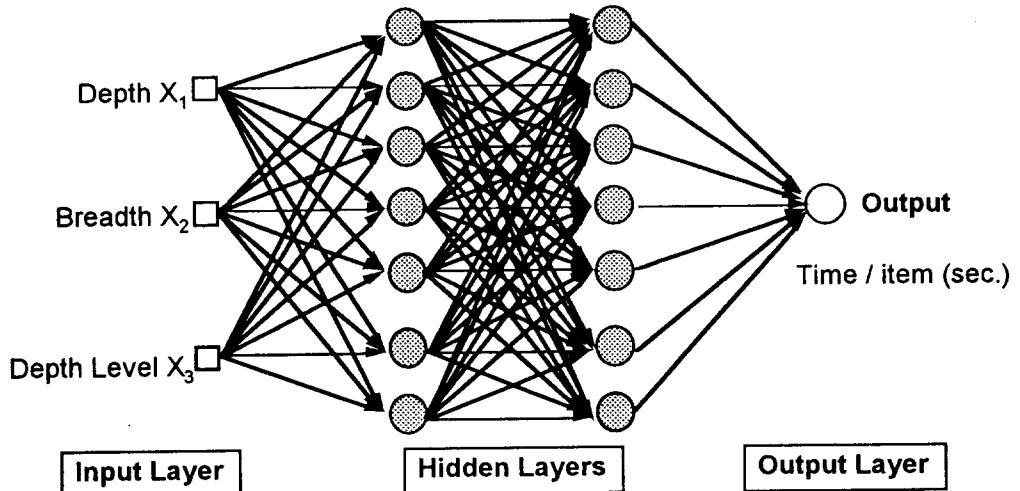


그림 2. t_i 에 대한 예측모델을 위한 Network의 구조

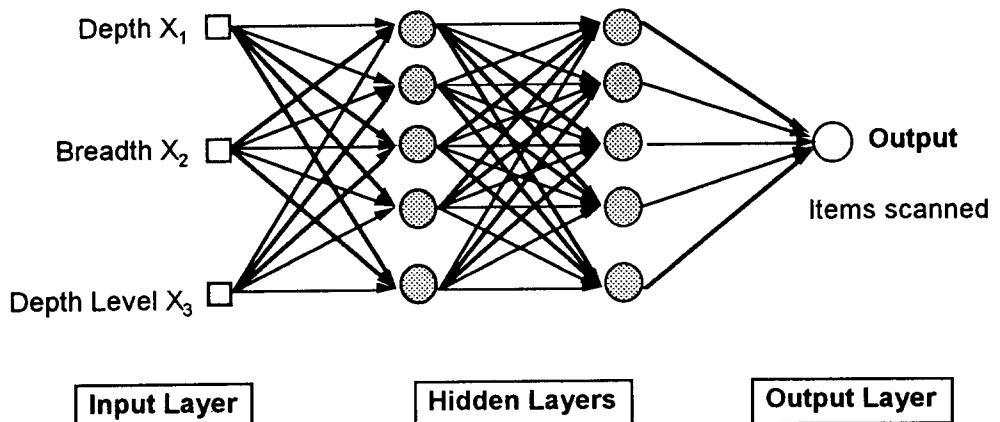


그림 4. $E(n_i)$ 에 대한 예측모델을 위한 Network의 구조

표 1. 학습결과 요약

	# Epochs	h	a	MSE (Learning)	MSE (Cross Validation)
t_i Model	2000	0.01	0.1	0.2971	0.3420
$E(n_i)$ Model	2000	0.01	0.01	0.0724	0.0913

개발된 예측모델은 실제 사용자의 수행도를 일정한 정확도로 예측할 수가 있어야 하며, 기존의 다른 모델들과 비교하여 예측의 정확도가 높아야 한다. 본 연구에서는 개발된 모델에 대한 평가를 위하여, 2명의 피실험자에 대하여 소규모 실험을 추가로 실시하였다. 실험에서는 64^1 , 8^2 , 4^3 , 2^6 의 네가지 메뉴구조를 평가하였으며, 각 피실험자가 한 메뉴구조를 4번씩 반복적으로 평가하여 평균 작업수행시간을 구하였다.

동일한 네가지 메뉴구조에 대하여 본 연구에서 개발된 NN Prediction Model과 전통적인 Model을 이용하여 추정한 작업수행시간을 표 2에 요약하였고, 이를 실험결과와 비교하여 도식화하면 그림 5와 같다. 그림에 나타난 바와 같이, 기존의 모델에 의한 예측치는 실험결과와 큰 차이를 보이는 반면, NN Model은 상당한 예측정확도를 보이는 것을 알 수 있다.

표 2. Search Time 비교

Menu Structure	Depth Level	NN Model			Conventional Model			(Time Unit: sec.) Ave. ST of Experiment
		E(n _i)	t _i	ST ₁	E(n)*	t**	ST ₂	
64^1	1	22.47	0.7352	16.52	32.5	1.8026	58.59	17
8^2	1	4.633	1.4201	15.56	4.5	1.8026	16.22	15.7
	2	4.947	1.8157					
4^3	1	2.698	1.4843	15.56	2.5	1.8026	13.52	23.9
	2	2.854	1.8408					
	3	3.007	2.0953					
2^6	1	1.84	1.5660	24.72	1.5	1.8026	16.22	35.6
	2	1.9	1.8349					
	3	1.97	2.0257					
	4	2.03	2.1717					
	5	2.09	2.2965					
	6	2.14	2.4118					

* E(n)=(Breadth+1)/2

** t: Average time per item

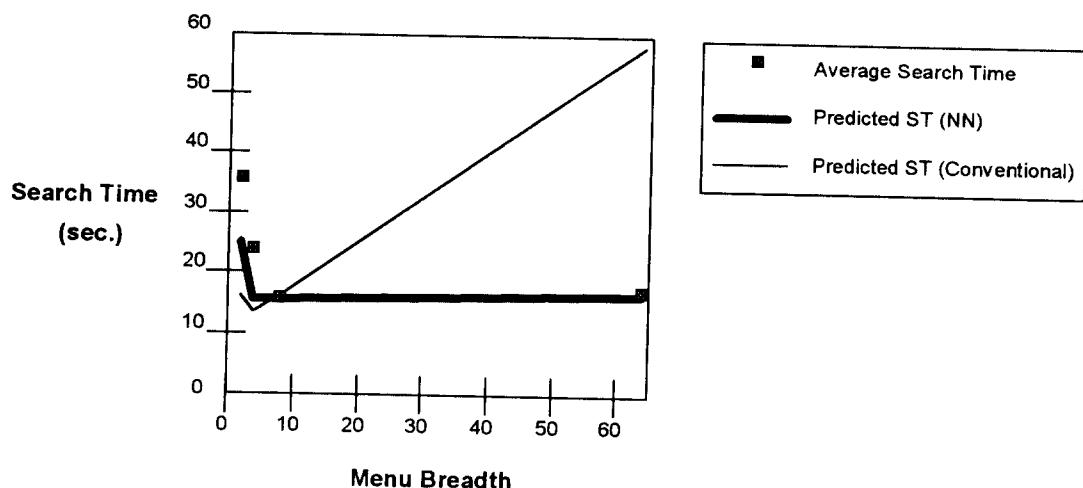


그림 5. Search Time 비교

5. 논의 및 추후연구과제

본 연구에서 신경회로망을 이용하여 개발된 SDM에 대한 수행도 예측모델은 다음과 같은 장점을 갖는다.

- 기존의 수행도 모델링에서는 메뉴항목을 찾는 데 소요되는 시간이 메뉴의 Depth Level의 변화와 무관하게 일정한 것으로 가정하였으나, 본 모델에서는 메뉴의 Depth Level을 반영한 시간을 이용함으로써, 예측의 정확도를 제고하였다.
- 같은 Depth Level의 메뉴항목 중 한 항목을 선택하기까지 검색하는 항목의 수를 Depth Level을 반영하여 예측하였다.
- Neural Network 기법을 이용함으로써, 각 Parameter의 예측에 Input 변수가 미치는 함수적인 상관관계를 추측하지 않고 Black-box Approach를 통해 접근하였다.
- Network에 학습된 적이 없는 Input Pattern, 즉, 16×4 , 4×16 등과 같은 다소 변화된 구조나 Depth Level 별로 Breadth가 달라지는 Assymmetric 구조의 메뉴에 대하여도 의미있는 예측치를 제공할 수 있다.
- Data Set이 제공되면 다른 설계변수를 적용하였을 경우에 대한 예측모델을 쉽게 재구성할 수 있다(예. Navigation Aid가 제공될 경우의 메뉴구조별 수행시간).

그러나, Trial-and-error Approach를 이용할 경우, 모델의 구축에 상당한 시간이 소요되며, 통계적 신뢰도 등을 제공할 수가 없다는 단점이 있으나, 수행도 예측모델의 구성이 설계단계에 미치는 영향과 중요성을 고려할 때 문제시되지 않을 것으로 판단된다.

본 연구에서 구성한 예측모델에 대한 검증을 위하여 보다 확장된 Formal Experiment가 필요하며, 다른 학습방법을 적용하거나 MLP 이외의 Network Model을 이용하는 등의 최적화가 필요할 것으로 판단된다.

참 고 문 헌

- [1] 곽지영, 한성호 (1995). 전자제품의 휴면 인터페이스 메뉴 설계 방안, '95 춘계 MS/IE 발표논문집.
- [2] Card, S. K. (1982). User perceptual mechanisms in the search of computer command menus. *Proceedings of Human Factors in Computing Systems*, 190-196.
- [3] Han, S. H. and Kwahk, J. (1994). Design of a menu for small displays presenting a single item at a time. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, pp.360-364, CA: Human Factors and Ergonomics Society.
- [4] Kwahk, J. and Han, S. H. (1994). Menu structure for single-line displays, *Proceedings of 3rd Pan-Pacific Conference on Ergonomics*, pp.
- [5] Landauer, T. K. and Nachbar, D. W. (1985). Selection from alphabetic and numeric trees using a touch screen: Breadth, depth and width. *CHI-85 Proceedings*, 73-78.
- [6] Lee, E., & MacGregor, J. (1985). Minimizing user search time in menu retrieval systems. *Human Factors*, 27, 157-162.
- [7] Paap , and Roske-Hofstrand (1986).The optimal number of menu options per panel. *Human Factors*, 28, 377-385.